

SEYREK KODLAMA VE ÇEVİRİMİÇİ SÖZLÜK ÖĞRENME KULLANILARAK HİBRİT HİPERSPETRAL GÖRÜNTÜ SIKIŞTIRMASI



İREM ÜLKÜ
ÇANKAYA ÜNİVERSİTESİ, ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ BÖLÜMÜ



1. Özeti

Seyrek kodlama tabanlı çeviriçi sözlük öğrenme yaklaşımını literatürde ilk kez hiperspektral görüntülerin sıkıştırılması için adapte eden hibrit bir yöntem önerilmiştir. Bu yöntemde, çeşitli seyrek temsil algoritmaları seyrek kodlama problemini çözmek amacıyla kullanılmıştır. Farklı seyrek temsil algoritmaları ile diğer sıkıştırma algoritmaları oran-bozulma performansları açısından karşılaştırılmışlardır. Bilgi koruma performansları da anomali tespit uygulaması ile ayrıca ölçülmüştür. Deneyel sonuçlar kanıtlıyor ki bit hızı arttıkça **yakınlık bazlı eniyileme ve kör sıkıştırma** algoritmalarına ait sıkıştırma performansları diğer algoritmalarдан üstün olmaktadır.

2. Problem Tanımı

Çeviriçi sözlük öğrenme:

Dönüşümlü bir süreçte aşağıdaki denklemler çözülür:

$$\begin{aligned} \text{1. Seyrek kodlama: } & \mathbf{a}_n = \min_{\mathbf{a}} \frac{1}{2} \|\mathbf{x}_n - \mathbf{D}_{n-1} \mathbf{a}\|^2 + \lambda \|\mathbf{a}\|_1 \\ \text{Girdi: } & \text{Rasgele örnek } \mathbf{x}_n, \text{ önceki sözlük } \mathbf{D}_{n-1} \\ \text{Çıktı: } & \text{Seyrek katsayılar } \mathbf{a} \\ \text{Çözüm: } & \text{Çeşitli seyrek temsil algoritmaları} \end{aligned}$$
$$\begin{aligned} \text{2. Sözlük güncelleme: } & \mathbf{D}_n = \min_{\mathbf{D}} \frac{1}{n} \sum_{i=1}^n \|\mathbf{x}_i - \mathbf{D} \mathbf{a}_i\|^2 + \lambda \|\mathbf{a}_i\|_1 \\ \text{Girdi: } & \text{Önceki seyrek katsayılar } \mathbf{a}_n, \text{ önceki örnekler } \mathbf{x}_i \\ \text{Çıktı: } & \text{Yeni sözlük } \mathbf{D}_n \\ \text{Çözüm: } & \text{Blok koordinat iniş yöntemi} \end{aligned}$$

*Mairal et. al. çalışmasında ispatlandığı üzere: Eğitim kümesi sonsuza giderken ampirik maaaliyet yerine beklenen maaaliyetin minimum değerini bulmak yeterlidir [1].

$$\begin{aligned} f(\mathbf{D}) &\triangleq E_{\mathbf{x}}[l(\mathbf{x}, \mathbf{D})] = \lim_{n \rightarrow \infty} f_n(\mathbf{D}) \\ \text{Ampirik maaaliyet} & \downarrow \quad \quad \quad \text{Denk maaaliyet} \downarrow \\ f_n(\mathbf{D}) &= \frac{1}{n} \sum_{i=1}^n l(\mathbf{x}_i, \mathbf{D}) \quad \quad \quad \hat{f}_n(\mathbf{D}) \triangleq \frac{1}{n} \sum_{i=1}^n l(\mathbf{x}_i, \mathbf{D}) \\ \text{Eşitlik 1 olasılık ile} & \text{yakınsanır} \end{aligned}$$

3. Algoritma

Algoritma 1

- Rastgele ilk sözlük \mathbf{D}_0 oluşturulur
- \mathbf{A}_0 ve \mathbf{B}_0 matrisleri ilk olarak sıfırlanır
- $t = 1, \dots, T$ için
 - Hiperspektral görüntünden rasgele $\mathbf{x}_t \in R^{n_b}$ örnek piksel seçilir
 - "seyrek kodlama problemi" çözülür → * Çözüm için çeşitli seyrek temsil algoritmaları kullanılmıştır.
 - $\mathbf{A}_t = \mathbf{A}_{t-1} + \mathbf{a}_t \mathbf{a}_t^T$ ve $\mathbf{B}_t = \mathbf{B}_{t-1} + \mathbf{x}_t \mathbf{x}_t^T$ güncellenir
 - Sözlük \mathbf{D}_t güncellemek için **Algoritma 2** kullanılır
 - En son öğrenilmiş \mathbf{D}_T sözlük bulunur

Algoritma 2

- tekrarla
- $j = 1, \dots, k$ için
- \mathbf{D}_t matrisinin j 'inci kolon değerleri güncellenir

$$\mathbf{D} = [\mathbf{d}_1, \dots, \mathbf{d}_k] \in R^{n_b \times k}, \mathbf{A} = [\mathbf{a}_1, \dots, \mathbf{a}_k] \in R^{k \times k} \text{ and } \mathbf{B} = [\mathbf{b}_1, \dots, \mathbf{b}_k] \in R^{n_b \times k}$$

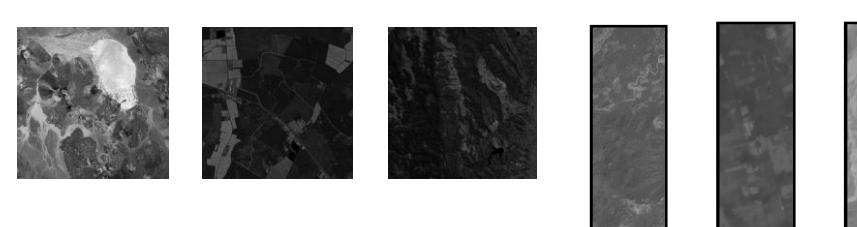
$$4: \mathbf{u}_j = \frac{1}{A(j,j)} (\mathbf{b}_j - \mathbf{D} \mathbf{a}_j) + \mathbf{d}_j \text{ and } \mathbf{d}_j = \frac{1}{\max(\|\mathbf{u}_j\|_2, 1)} \mathbf{u}_j \text{ and } E_j = \sqrt{\sum_{n_b} |\mathbf{d}_j^n - \mathbf{d}_j^{n-1}|^2}$$

$$6: E = \frac{1}{k} \sum_{j=1}^k E_j$$

7: gerçekleşenede kadar $E < \text{Eşik değeri}$

8: Yeni sözlük \mathbf{D} **Algoritma 1** içinde kullanılır

Kullanılan Datasetleri:

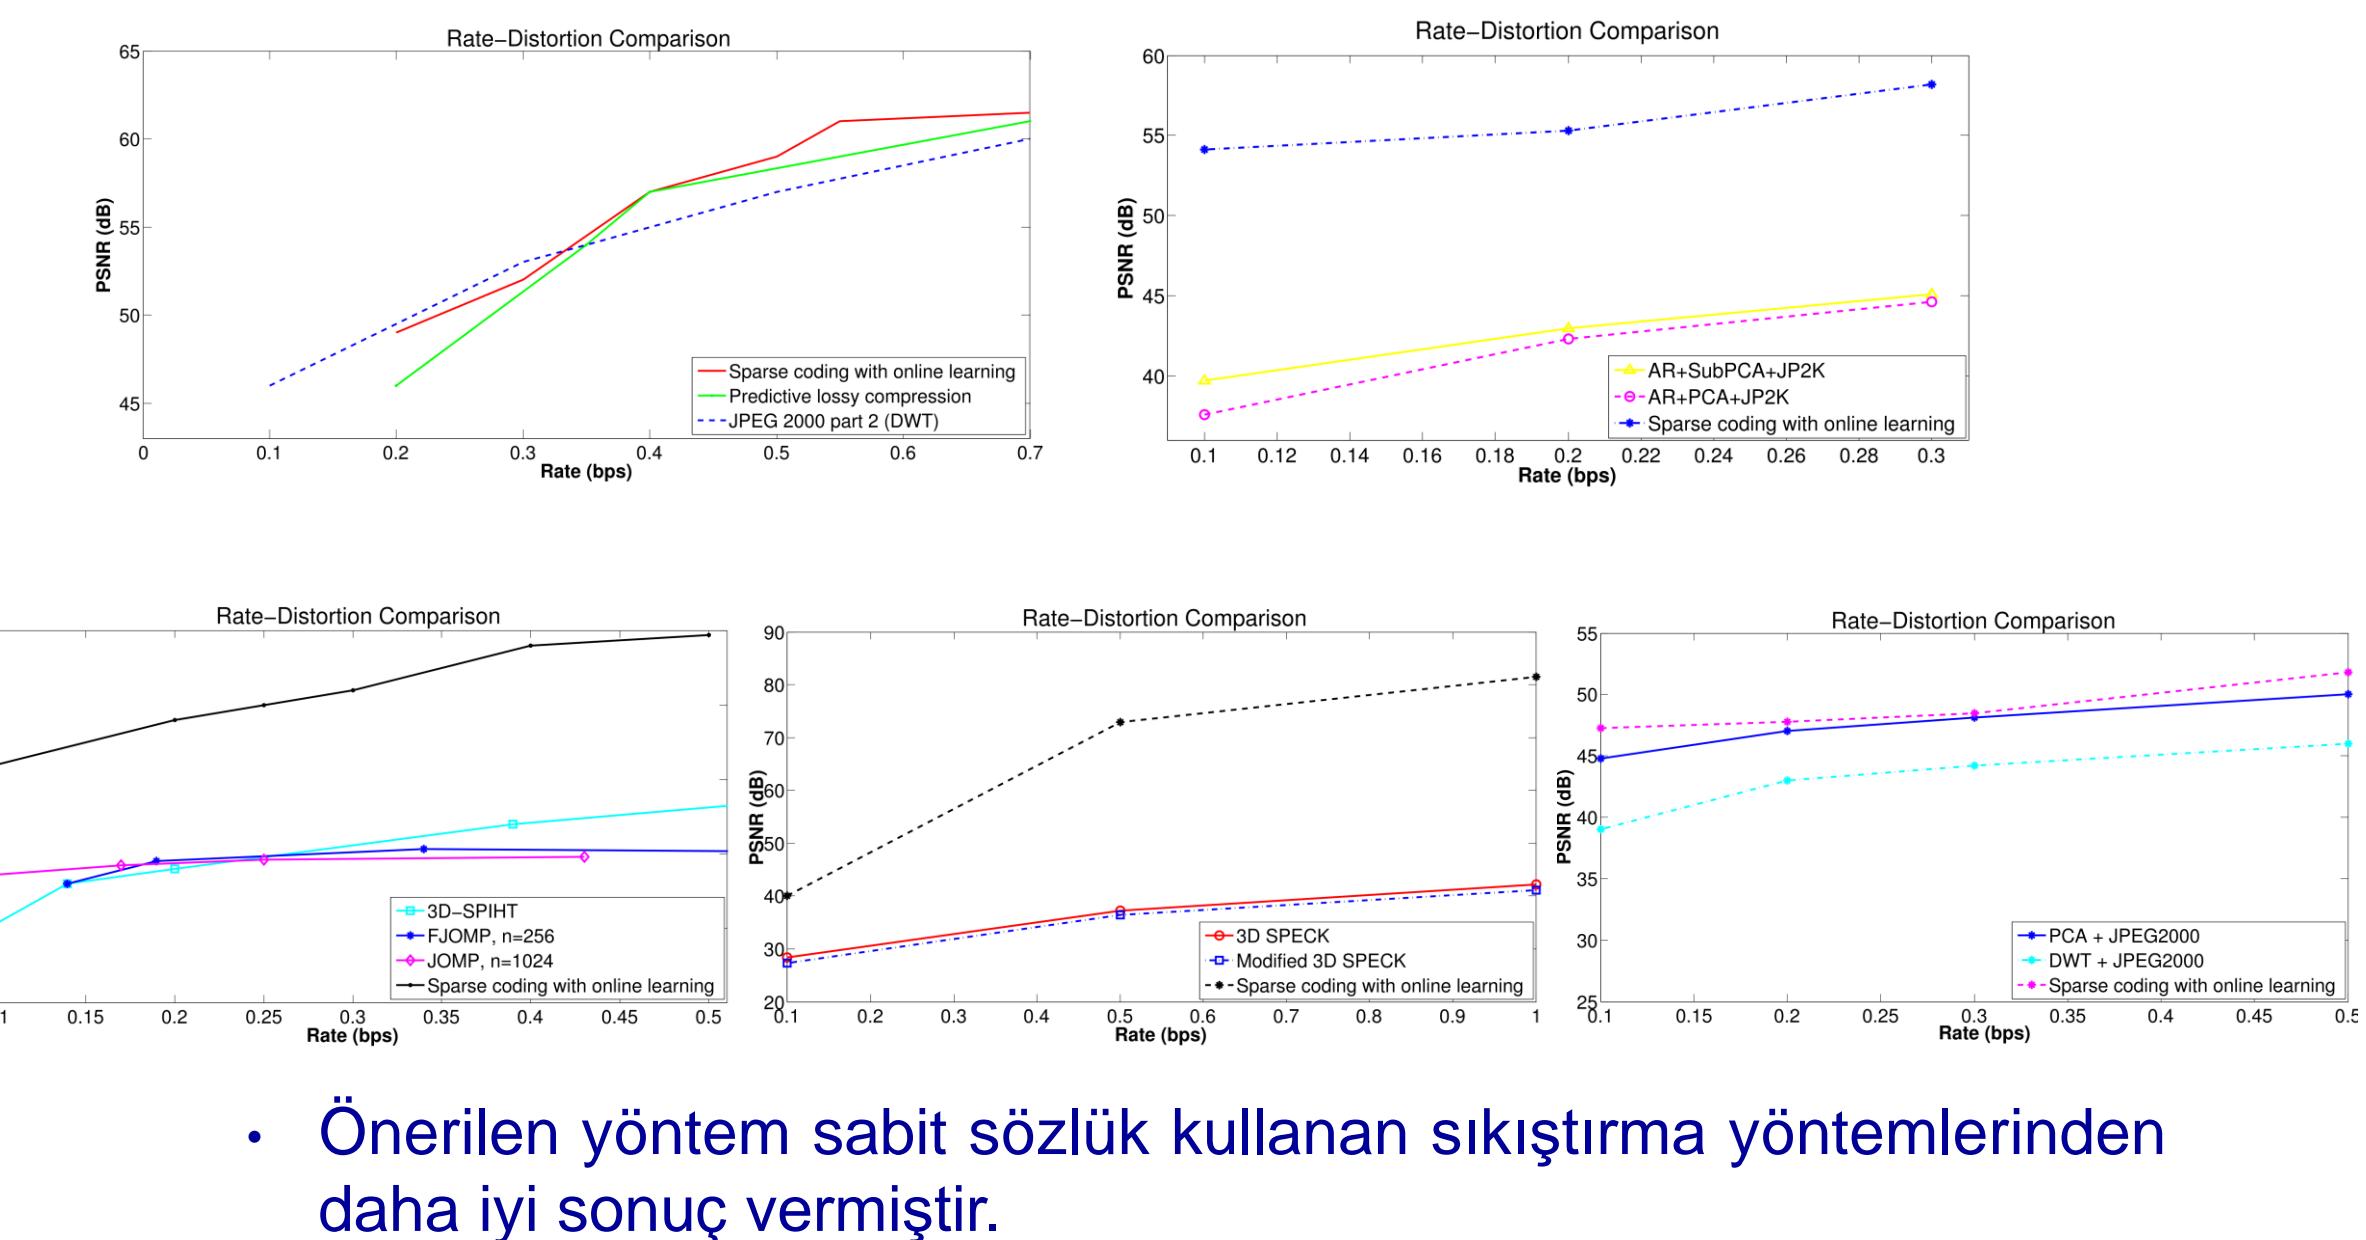


AVIRIS, HYPERION ve ROSIS sensörlerine ait hiperspektral görüntüler kullanılmıştır.

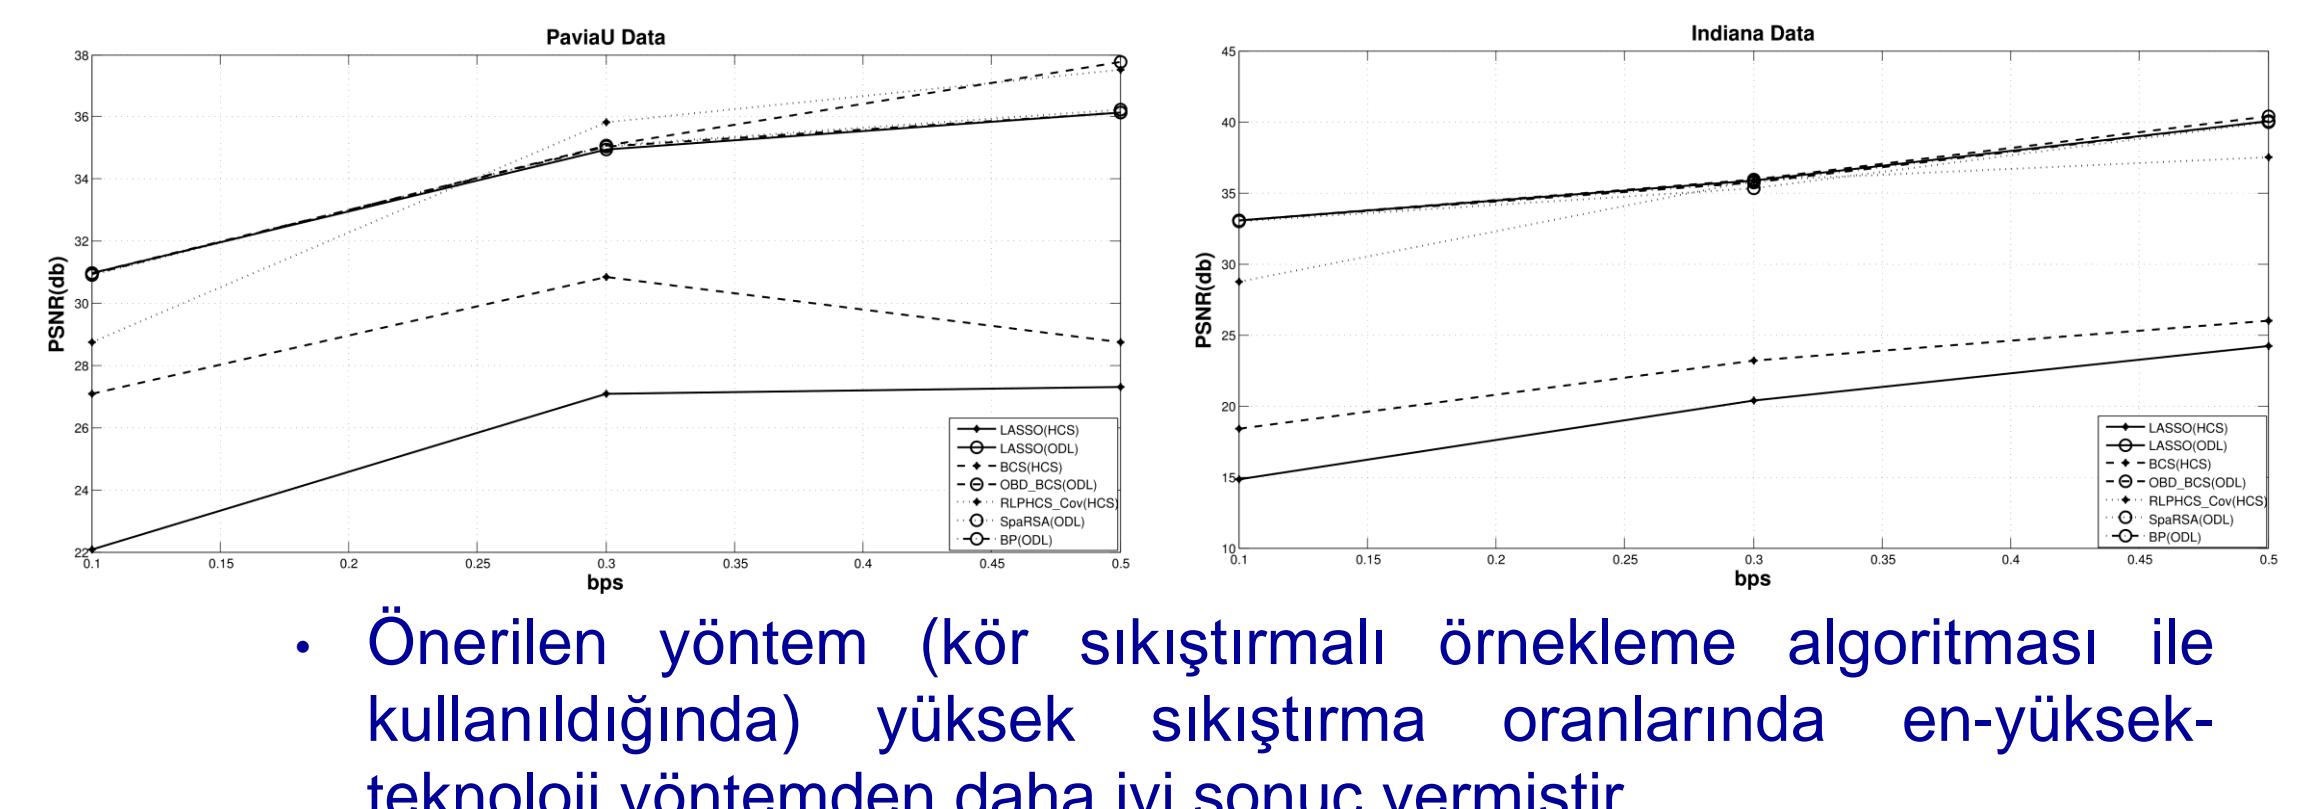
İREM ÜLKÜ

4. Deneyler

Oran-Bozulma Performansları:

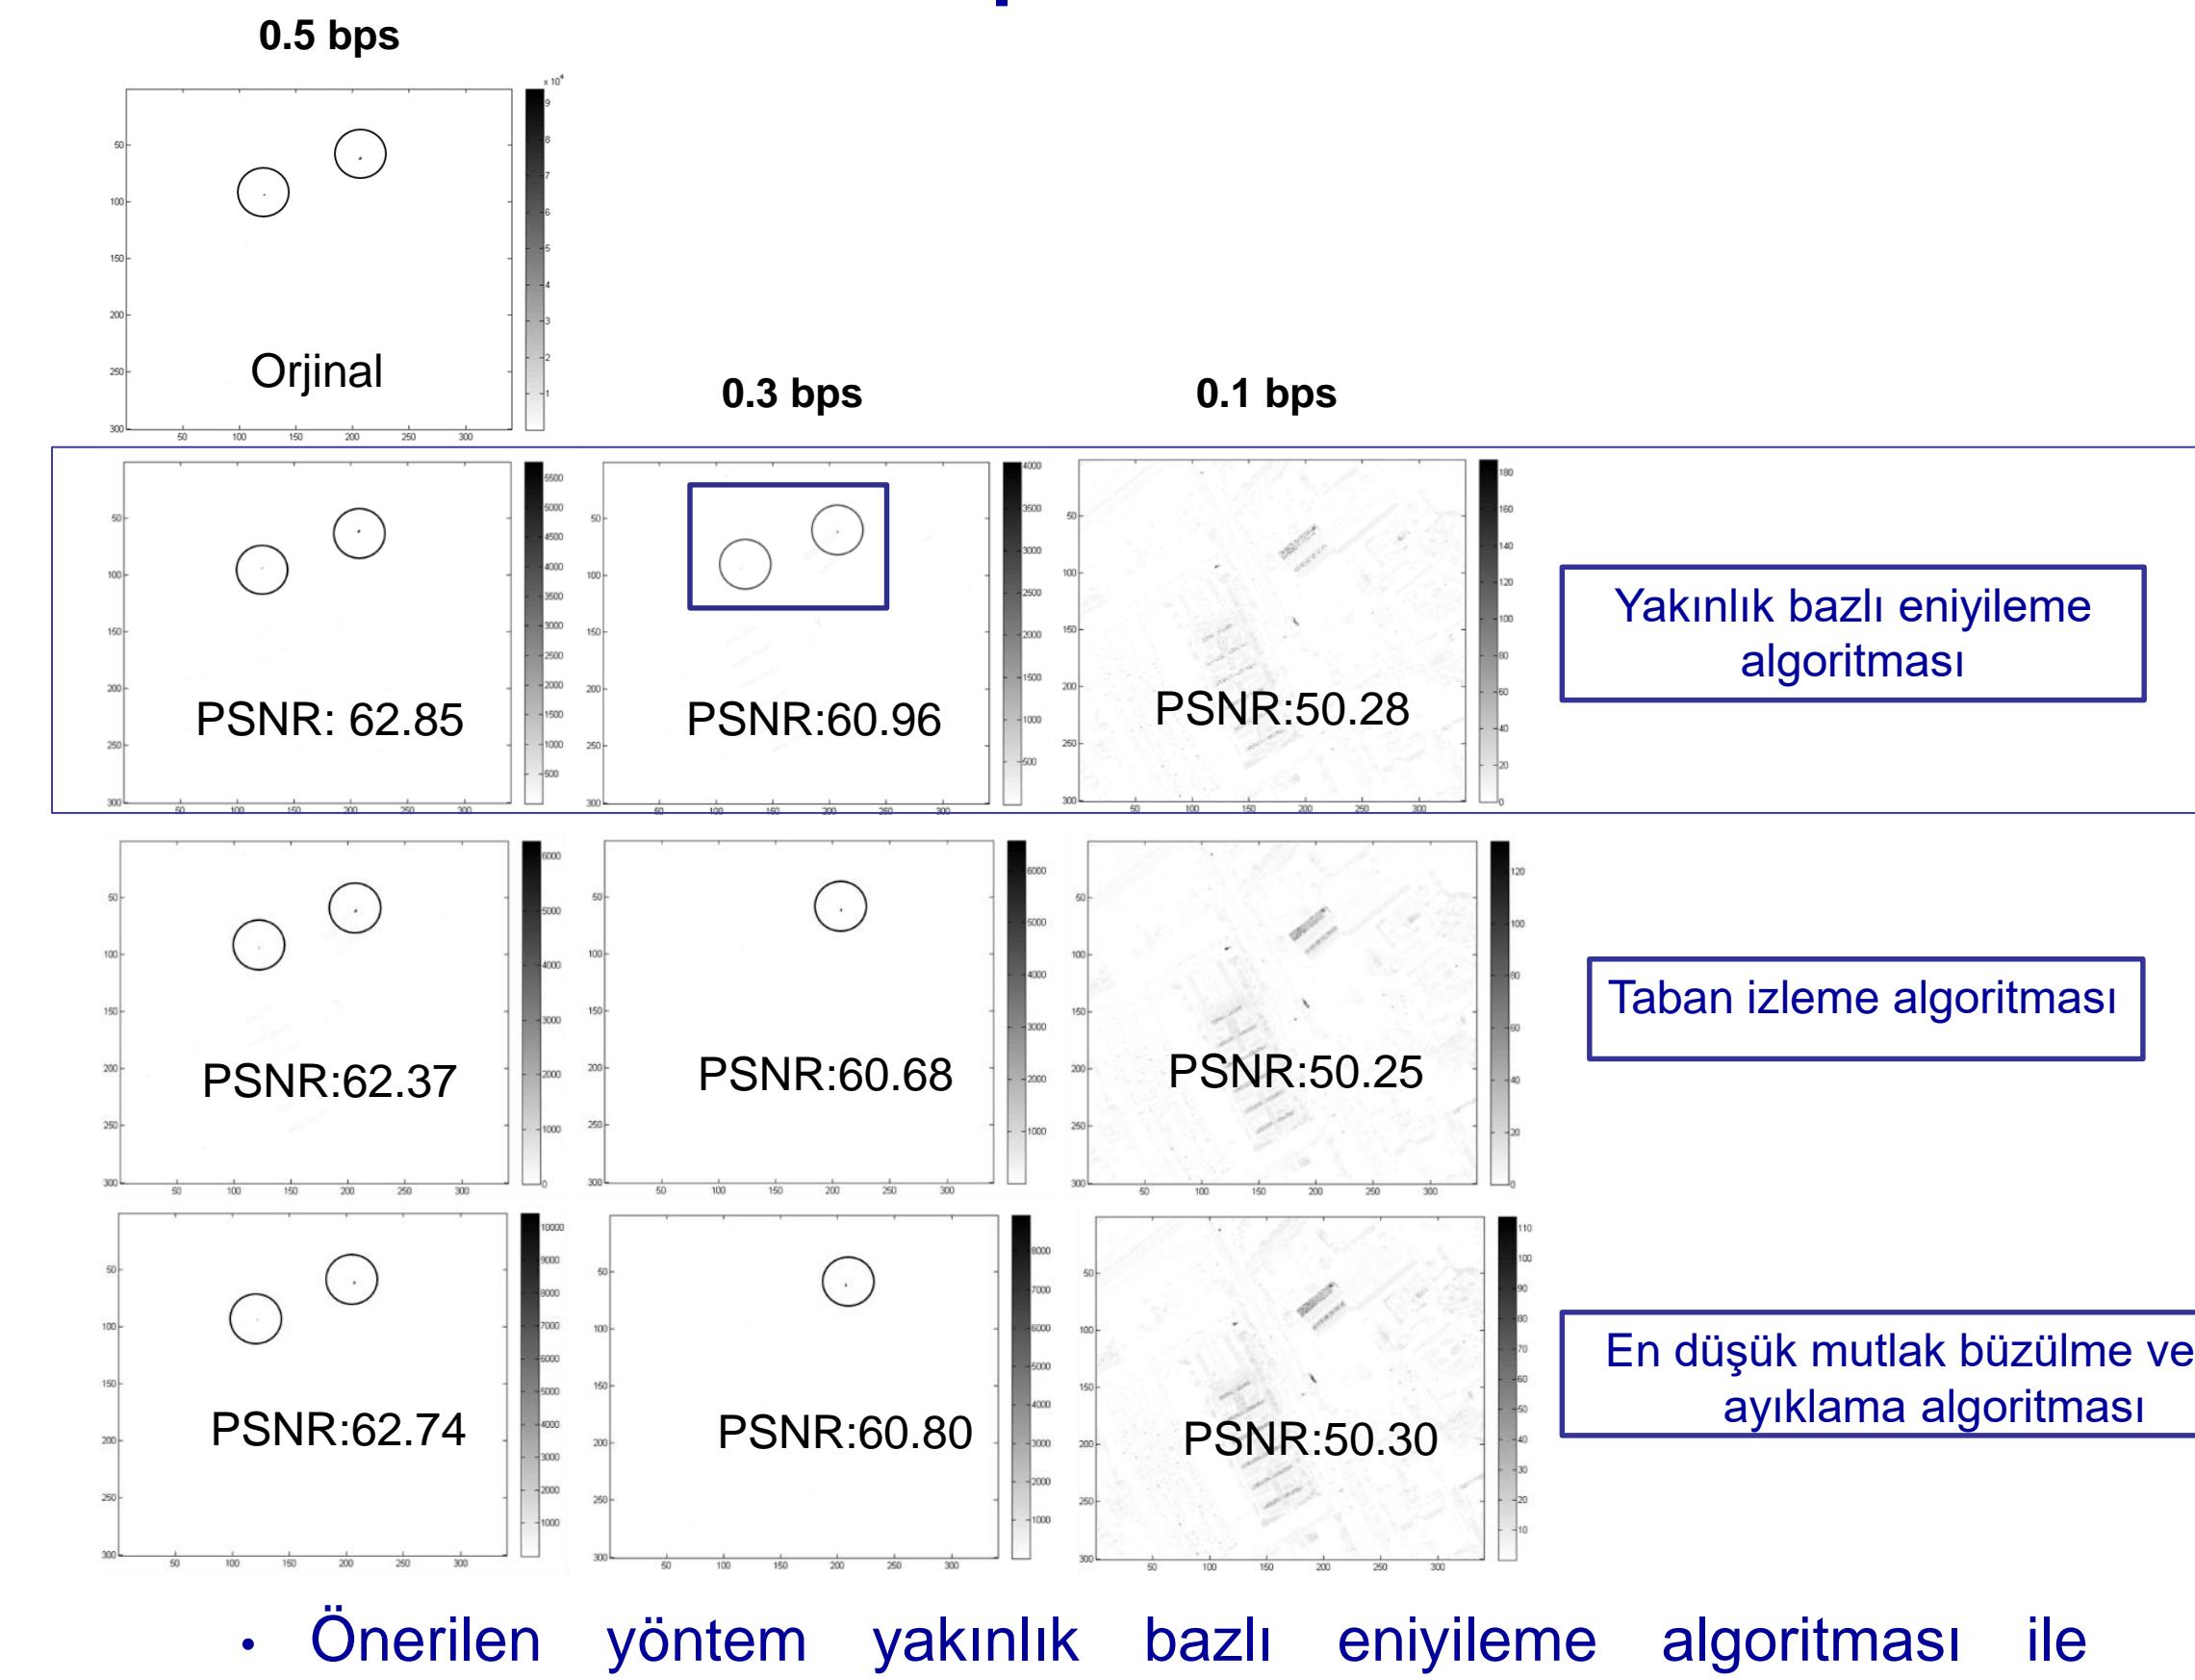


- Önerilen yöntem sabit sözlük kullanan sıkıştırma yöntemlerinden daha iyi sonuç vermiştir.



- Önerilen yöntem (kör sıkıştırma) yüksek sıkıştırma oranlarında en-yüksek teknoloji yöntemden daha iyi sonuç vermiştir.

Anomali Tespit Performansları:



- Önerilen yöntem yakınlık bazlı eniyileme algoritması ile kullanıldığından yüksek sıkıştırma oranlarında diğer algoritmalarдан daha iyi sonuç vermiştir.

5. Sonuçlar

* Mairal et. al. çalışmasında önerilen çeviriçi sözlük öğrenme yöntemi literatürde ilk kez sıkıştırma amacıyla üç boyutlu hiperspektral görüntülere göre adapte edilmiştir. Önerilen bu hibrit yöntem en-ileri-teknoloji yöntemler de dahil literatürdeki bütün yöntemlerden daha iyi performans göstermiştir.

* Yöntem çeşitli seyrek temsil algoritmaları ile kullanılmıştır. **Yakınlık bazlı eniyileme** ve **kör sıkıştırma** algoritmaları ile kullanıldığından 0.5 bps ve üzerindeki sıkıştırma oranlarında en iyi sonuçlar alınmıştır [2].

* Örnek olarak AIRBUS'a ait Pleiades uydusunun 3 bps gibi yüksek sıkıştırma oranlarında hiperspektral görüntü sıkıştırması gerçekleştirtiği bilindiği için, önerilen yöntemin gerçek hayatı yüksek sıkıştırma gerçekleştirmek için kullanılabilceği düşünülmektedir.

Referanslar

- MAIRAL, J., BACH, F. et. al. (2010) Online learning for matrix factorization and sparse coding, Journal of Machine Learning Research, 19-60. vol. 11.
- ÜLKÜ I., TÖREYİN, B. U. (2015) Sparse representations for online-learning-based hyperspectral image compression, Applied optics, 8625-8631. vol. 54.